

Aplicación de PSO y GAs a la síntesis de agrupaciones lineales de antenas

Marcos A. Correa Javier Villanueva Jesús R. Pérez José Basterrechea
ETSIIT. Dpto. Ingeniería de Comunicaciones
Universidad de Cantabria
e-mail : basterrj@unican.es, perezjr@unican.es

Abstract- Genetic algorithms (GAs) and Particle Swarm Optimization (PSO) are commonly used to solve many optimization and synthesis problems. An important issue facing the user is the selection of their parameters, such as crossover and mutation strategies and rates in GAs, or the population size and boundary conditions in PSO. This paper shows an exhaustive process to obtain those parameters and demonstrates that PSO is more efficient than the real-valued GA when both are applied to linear array synthesis. PSO, with less computational burden and generally fewer lines of code than GAs, turns out to be a more efficient algorithm for the design problem analyzed.

I. INTRODUCCIÓN

Como alternativa a las teorías clásicas, los métodos de optimización estocástica están adquiriendo cada vez más importancia dentro del campo de la síntesis electromagnética. Basándose en la teoría de Darwin de la evolución y en el estudio del sincronismo de los bancos de peces y las bandadas de aves, surgen, respectivamente, los algoritmos genéticos (GAs) y la optimización con enjambre de Partículas, más conocido entre la comunidad científica como PSO.

En este artículo se va a efectuar una comparación entre ambos métodos de optimización con el objetivo de comprobar si pueden aplicarse eficientemente a problemas de síntesis de alimentaciones de agrupaciones lineales de antenas. Esta síntesis se reduce básicamente a estimar los fasores de la distribución de corriente de cada uno de los elementos que conforman la agrupación, de forma que cumplan con unas condiciones de radiación sujetas a unas especificaciones de partida en forma de máscara. De este modo se dispone de un método válido para cubrir, con una cierta agrupación, una zona geográfica determinada.

El estudio del comportamiento de una agrupación lineal de antenas puede, en primera aproximación, reducirse al estudio de su factor de agrupación, dado por (1), [1].

$$FA(\theta) = \sum_{n=1}^N a_n \cdot e^{j \cdot (((n-1) \cdot k \cdot d \cdot \cos(\theta)) + \alpha_n)} \quad (1)$$

donde N es el número de antenas o elementos radiantes de la agrupación, a_n es el módulo de la distribución de corriente de cada antena, $k = 2\pi/\lambda$ es la constante de propagación, d es la distancia entre los radiadores, θ es el ángulo con respecto al

eje de la agrupación, y α_n es la fase de la distribución de corriente de cada antena, siendo a_n y α_n los parámetros a optimizar.

Para hacer un estudio comparativo entre ambos métodos globales de optimización, es necesario efectuar antes un proceso de parametrización que permita establecer para cada algoritmo, su configuración óptima para su aplicación al problema electromagnético propuesto. Realizada la puesta a punto de los algoritmos se está en disposición de aplicarlos a la síntesis de estructuras lineales más complejas.

II. MÉTODOS DE OPTIMIZACIÓN: GAs Y PSO

Los algoritmos genéticos constituyen un método de optimización cuya popularidad ha crecido notablemente durante la última década. Como no podía ser de otro modo, esta tendencia se ha ido extendiendo a múltiples campos de investigación, entre los que se encuentra la síntesis y optimización electromagnética en muy diversas áreas.

En los GAs un conjunto de soluciones potenciales - población- se somete a un proceso de evolución que conduce a una solución óptima global. Dicha evolución se lleva a cabo a través de un proceso de selección sopesado por la denominada función de *fitness*, y la exploración del espacio de soluciones se realiza por medio de procesos de recombinación y mutación de las características genéticas asociadas con cada uno de los cromosomas de la población. De las múltiples variantes de GAs existentes (GAs de codificación real, binaria, híbridos, microgenéticos, etc), en este artículo se utilizan los GAs de codificación real con diferentes estrategias para los operadores de cruce y mutación [2]: cruce discreto, continuo, convexo/aritmético y heurístico, y mutación creep 3%, boundary, uniforme, no uniforme y multi no uniforme. Al margen de las estrategias estándar, también se hace uso de variaciones de las mismas [3].

El algoritmo de optimización PSO constituye una alternativa seria a los GAs, y nace en un intento por trasladar al campo de la optimización el comportamiento social que exhiben comunidades de organismos tales como las abejas, las aves o los peces en su desplazamiento en busca de alimento. En PSO, cada individuo de la población representa una posible solución dentro del espacio de soluciones N -dimensional y, junto con el resto de sus congéneres, recorre el espacio en busca de la solución óptima, utilizando, al igual que los GAs, una función de *fitness* para cuantificar la calidad de su vector de posición. El desplazamiento sobre el espacio de soluciones viene dado por la adaptación de los vectores velocidad (2) y posición (3) de cada partícula [4]. A

la velocidad de la partícula contribuyen dos componentes fundamentales: la inercia (ω), que indica la probabilidad que presenta la partícula para continuar en la dirección en la que viaja por el espacio de soluciones, y las constantes de aceleración C_1 y C_2 .

$$v_n = \omega \times v_n + C_1 \times rand() \times (P_{best,n} - x_n) + C_2 \times rand() \times (G_{best,n} - x_n) \quad (2)$$

$$x_n = x_n + v_n \quad (3)$$

En (2) v_n representa la velocidad en la dimensión n -ésima, C_1 es la constante de aceleración 1 o memoria, e indica el grado en el que influyen los resultados propios de un individuo, C_2 es la constante de aceleración 2 o cooperación, que indica la influencia del resto de individuos, $rand$ es un número aleatorio, P_{best} es la mejor posición local encontrada por el individuo hasta el momento, G_{best} es la mejor posición global encontrada por toda la población de individuos hasta el momento y x_n es la posición de la partícula en la dimensión n .

En términos de complejidad, el PSO es más sencillo de implementar que los GAs, puesto que sólo existe un operador, la velocidad de partícula, frente a los operadores de selección, cruce y mutación inherentes a los GAs, cada uno de los cuales a su vez admite diferentes estrategias de implementación. Al margen de los operadores, en el PSO clásico sólo hay que fijar la población, velocidad máxima de partícula, peso inercial y constantes de aceleración, existiendo valores típicos que reducen la selección al tamaño de la población en la versión más simplificada. En los GAs, hay que añadirle a la selección de la población, el ajuste de las tasas de cruce y mutación.

III. RESULTADOS

Para realizar la síntesis de agrupaciones lineales de antenas por medio de los dos métodos de optimización, es necesario obtener estadísticamente los parámetros óptimos para cada algoritmo de optimización. En ambos optimizadores, el único nexo de unión entre el problema físico y el algoritmo es la función de fitness. Por lo tanto, el primer paso debe centrarse en seleccionar adecuadamente la expresión del fitness que depare un coste computacional mínimo. Se define, pues, un problema canónico sencillo formado por una agrupación lineal de 15 elementos equiespaciados $\lambda/2$, que será utilizado para la búsqueda de la función fitness adecuada y para la puesta a punto de los optimizadores.

Después de encontrar la configuración óptima para cada método de optimización se aplicarán ambos algoritmos a un problema más complejo de síntesis de una agrupación con 30 elementos equiespaciados $\lambda/2$.

A. Elección de la función fitness

Con el objetivo de buscar el equilibrio entre precisión en las soluciones y coste computacional, se propone la búsqueda de una función de fitness que se adecue al problema a resolver. Para deducir una fórmula válida se ha efectuado una

búsqueda bibliográfica [5, 6] para obtener puntos de partida razonables. Como resultado se seleccionaron dos funciones de fitness (4) y (5) que, en principio, ofrecían resultados aceptables, y se introdujo una modificación para obtener una tercera (6).

$$F_n = 1 / (1 + \left(\sqrt{\frac{1}{M} \cdot \sum_{i=1}^M \left| \frac{AF_{limit}(\theta_i) - AF(\theta_i)}{AF_{limit}(\theta_i)} \right|^2} \right)) \quad (4)$$

$$F_n = 1 / (1 + \left(\sum_{i=1}^M \max(|AF(\theta_i)| - |AF_{máxlimit}(\theta_i)|, 0)^2 + \sum_{i=1}^M \max(|AF_{mínlimit}(\theta_i)| - |AF(\theta_i)|, 0)^2 \right)) \quad (5)$$

$$F_n = 1 / (1 + \left(\sum_{i=1}^M \min_{dB}(|AF(\theta_i)| - |AF_{máxlimit}(\theta_i)|, 0)^2 + \sum_{i=1}^M \min_{dB}(|AF_{mínlimit}(\theta_i)| - |AF(\theta_i)|, 0)^2 \right)) \quad (6)$$

En las ecuaciones (4) a (6), M es el número de puntos conocidos del diagrama de radiación, AF_{limit} es la máscara impuesta que condiciona la radiación de la agrupación, AF es el propio diagrama de radiación de la agrupación, y θ es el ángulo de barrido espacial.

Para cada uno de los métodos de optimización se han realizado 15 simulaciones independientes en las que se estudia el comportamiento de cada una de las funciones propuestas. En las Figs. 1 y 2 se muestra la influencia de la función de fitness sobre los resultados para una realización concreta y para ambos optimizadores, GAs y PSO. Los resultados muestran que las funciones (5) y (6) son apropiadas para el problema. Sin embargo, dada su rapidez de convergencia para situaciones similares, se optó por utilizar la función (6) durante el resto del estudio, analizando si es realmente capaz de ajustarse a diferentes circunstancias, como son la presencia de nulos en la máscara o el cambio de apuntamiento de la misma.




Fig. 1. Factor de array. Efecto de la función de fitness sobre el rendimiento de los GAs.




Fig. 2. Factor de array. Efecto de la función de fitness sobre el rendimiento del PSO.

B. Puesta a punto de los algoritmos

Se hace necesario parametrizar ambos optimizadores con vistas a poder realizar la síntesis de agrupaciones lineales minimizando el tiempo de CPU. Para tal propósito, y en lo que respecta a los GAs, se inicia el estudio analizando la estrategia de cruce más recomendable, manteniendo invariables el resto de los parámetros. Haciendo uso de los datos obtenidos en estudios previos, se parte de una configuración inicial típica con mutación no uniforme, probabilidades de cruce y mutación $P_{\text{cruce}}=70\%$ y $P_{\text{mutación}}=5\%$ y una población de 60 individuos, que coincide con el doble del número de parámetros a optimizar (excitación compleja de los 15 elementos de la agrupación). La comparativa de las estrategias de cruce se muestra en la Fig. 3.




Fig. 3. Análisis de los GAs. Evolución del fitness máximo medio para cada estrategia de cruce.

Tal y como se deduce de la Fig. 3, la estrategia óptima para el operador de cruce es el cruce discreto. A continuación se analiza qué estrategia de mutación es la adecuada. Se mantienen invariables las probabilidades de cruce y mutación así como el tamaño de la población, considerando el cruce discreto en el análisis. De los resultados del análisis de la

mutación mostrados en la Fig. 4 se puede concluir que la estrategia óptima para el operador de mutación a emplear en problemas de síntesis de agrupaciones lineales mediante algoritmos genéticos con codificación real es la mutación no uniforme.




Fig. 4. Análisis de los GAs. Evolución del fitness máximo medio para cada estrategia de mutación.

En lo que respecta al PSO, el análisis se inicia utilizando una configuración típica de partida con parámetros $\omega=0.729$ y $C_1=C_2=1.49445$. Se realiza un estudio de la influencia sobre el rendimiento del optimizador de parámetros tales como la población, la velocidad máxima permitida a las partículas, el tipo de pared límite [4] y los tipos de PSO clásicos existentes en sus versiones global y local, aunque solo se muestren a modo representativo en la Fig. 5 los resultados de estos últimos.




Fig. 5. Análisis del PSO. Evolución del fitness máximo para diferentes esquemas del algoritmo.

A modo de resumen, en las Tablas 1 y 2 se expone la configuración óptima para cada uno de los métodos de optimización investigados. Debe resaltarse que estos resultados son aplicables al problema bajo estudio, no siendo necesariamente extrapolables a otras aplicaciones de diseño electromagnético.

PARÁMETROS ÓPTIMOS DEL GA	
Parámetro	Valor
Población	$4 \times N$
Método de Cruce	Discreto
P_{Cruce}	[70%,80%]
Método de mutación	No uniforme
$P_{\text{mutación}}$	5%

Tabla 1. Parámetros óptimos de los GAs

PARÁMETROS ÓPTIMOS DEL PSO				
Parámetro	Valor			
Tipo de PSO	Global Asíncrono			
Pared Límite	Invisible			
Peso inercial		ω	C_1	C_2
	Constante	0.729	1.49445	1.49445
Población	[50,75]			
Velocidad	[80%,100%]			

Tabla 2. Parámetros óptimos del PSO

C. Comparación entre GAs y PSO

Una vez se han sintonizado GAs y PSO se efectúa una comparación entre ambos. Para ello, se hace uso de una máscara en la que se fuerza a una agrupación lineal formada por 30 elementos equiespaciados $\lambda/2$ a apuntar en una determinada dirección. Además, se hace más restrictivo el problema haciendo que la máscara presente un nulo. Se realizan 5 simulaciones independientes con ambos métodos de optimización y se muestra en las Figs. 6 y 7 el resultado obtenido para la mejor de las cinco realizaciones. A la vista de los resultados obtenidos se puede establecer que ambos optimizadores ofrecen un comportamiento aceptable, aunque factores tales como la sencillez de implementación y la mayor rapidez de convergencia hace que el rendimiento del PSO sea superior al de los GAs. No debe llevar a engaño la Fig. 6, dado que los GAs utilizaron una población de 120 individuos y el PSO sólo de 60, de tal forma que para alcanzar el fitness de valor unidad se requieren en los GAs 7.2×10^5 llamadas al fitness y en PSO sólo la mitad.




Fig. 6. Ejemplo de aplicación con apuntamiento y nulo.




Fig. 7. Comparación del fitness máximo.

IV. CONCLUSIONES

La aplicación de técnicas de optimización global a cualquier problema de diseño electromagnético requiere sintonizar el algoritmo para la aplicación en concreto. En este trabajo se muestra un análisis comparativo entre PSO y GAs aplicados a la síntesis de alimentaciones en agrupaciones lineales de antenas. El estudio paramétrico inicial permite determinar que conjunto de parámetros definen la configuración óptima del algoritmo para la aplicación bajo análisis.

La comparación entre ambos métodos permite concluir que aunque son válidos para la síntesis de arrays, la sencillez de implementación, ajuste y rapidez de convergencia priman al PSO frente a los GAs.

AGRADECIMIENTOS

Este trabajo ha sido financiado en parte por la beca AP2001-1325 de la Secretaría de Estado de Educación y Universidades.

REFERENCIAS

- [1] C.A. Balanis, "Antenna theory: analysis and design", 2ª Ed., John Wiley & Sons, págs. 249-329, 1997.
- [2] D. Dumitrescu, B. Lazzerini, L.C. Jain, A. Dumitrescu, "Evolutionary computation", The CRC press international series on computational intelligence, 2000.
- [3] C.R. Houck, J.A. Joines, M.G. Kay, "A genetic algorithm for function optimization: a MATLAB implementation", North Carolina State University (NCSU), 1998.
- [4] J. Robinson, Y. Rahmat-Samii, "Particle Swarm Optimization in Electromagnetics", IEEE transactions on antennas and propagation, vol. 52, n°2, págs. 397-407, Febrero de 2004.
- [5] D.W. Boeringer, D.H. Werner, D.W. Machuga, "A simultaneous parameter adaptation scheme for genetic algorithms with application to phased array synthesis", IEEE transactions on antennas and propagation, vol. 53, n°1, págs. 336-371, Enero de 2005.
- [6] J.A. Rodríguez, F. Ares, E. Moreno, G. Franceschetti, "Genetic algorithm procedure for linear array failure correction", Electronics Letters, vol.36, n°3, págs. 196-198, Febrero 2000.